

KLASIFIKASI JENIS SAMPAH BERBASIS CONVOLUTIONAL NEURAL NETWORK DENGAN OPTIMASI HYPERPARAMETER TUNING ARSITEKTUR MOBILENET

Dimas Febri Kuncoro[✉], Anggit Wirasto, Deny Nugroho Triwibowo

Universitas Harapan Bangsa, Purwokerto, Indonesia

Email: dimasfebry9@gmail.com

DOI: <https://doi.org/10.46880/jmika.Vol9No1.pp130-144>

ABSTRACT

Waste management in Indonesia faces significant challenges with an increasing volume reaching approximately 175,000 tons per day. Public awareness of the dangers associated with improper waste disposal remains low, as many continue to litter indiscriminately. Waste sorting is the most effective method, involving separation based on waste types. Manual waste sorting is nonetheless inefficient, as it requires large spaces, substantial labor, and is prone to errors. This study aims to develop a waste classification model based on Convolutional Neural Network (CNN) with hyperparameter tuning optimization for the MobileNet architecture. The research adopts the Cross-Industry Standard Process for Data Mining (CRISP-DM) methodology and utilizes datasets from three waste categories organic, inorganic, and hazardous and toxic materials (B3) sourced from open Kaggle datasets. Model training was conducted using the MobileNet architecture with hyperparameter tuning optimization and resulting in optimal parameters Adam optimizer, learning rate of 0.01, batch size of 32, and 256 neurons. The results show that the model achieved 96% accuracy before optimization which increased by 2% to 98% after optimization. The model demonstrated high computational efficiency with the number of floating-point operations per second reaching 1.146 GFLOPS.

Keyword: Convolutional Neural Network (CNN), Computational Efficiency, Hyperparameter Tuning, MobileNet, Waste Management.

ABSTRAK

Pengelolaan sampah di Indonesia menghadapi tantangan besar dengan jumlah yang terus meningkat mencapai sekitar 175.000 ton per hari. Kesadaran masyarakat terhadap bahaya terkait dengan sampah masih rendah dengan membuang sampah sembarangan. Metode pemilahan sampah merupakan metode paling efektif dengan memisahkan sampah berdasarkan jenisnya. Pemilahan sampah secara manual tidak efektif karena membutuhkan ruang yang luas, tenaga kerja yang banyak, dan rentan terjadi kesalahan. Penelitian ini bertujuan membangun model klasifikasi jenis sampah berbasis Convolutional Neural Network dengan optimasi hyperparameter tuning arsitektur MobileNet. Penelitian dikembangkan dengan metode Cross-Industry Standard Process for Data Mining (CRISP-DM) serta menggunakan dataset terdiri dari tiga kategori sampah yaitu organik, anorganik, dan B3 yang bersumber dari dataset terbuka Kaggle. Pelatihan model dilakukan menggunakan arsitektur MobileNet dengan optimasi hyperparameter tuning dan memperoleh parameter optimal berupa optimizer Adam, learning rate 0.01, batch size 32, dan jumlah neuron 256. Hasil penelitian menunjukkan model berhasil mencapai akurasi sebesar 96% sebelum optimasi dan mengalami peningkatan 2% menjadi 98% sesudah optimasi. Biaya komputasi model menunjukkan nilai efisiensi tinggi dengan jumlah operasi floating point yang dapat dijalankan oleh model dalam satu detik adalah 1.146 GFLOPS.

Kata Kunci: Convolutional Neural Network (CNN), Efisiensi Komputasi, Hyperparameter Tuning, MobileNet, Pengelolaan Sampah.

PENDAHULUAN

Tantangan dan solusi dalam pengelolaan sampah di Indonesia semakin mendesak seiring dengan pesatnya pertumbuhan populasi dan perkembangan urbanisasi yang terus meningkat (Julia Lingga et al., 2024). Indonesia adalah salah satu negara berkembang dengan populasi terbesar keempat di dunia. Kondisi ini

menjadi salah satu faktor mengapa Indonesia menjadi negara penghasil dan penyumbang sampah terbesar kedua di dunia (Sulistio & Syahruddin, 2024). Kementerian Lingkungan Hidup dan Kehutanan (KLHK) mengungkapkan bahwa volume sampah yang menumpuk di Indonesia mengalami peningkatan signifikan, mencapai sekitar 175.000 ton per hari. Jika

diakumulasi jumlah ini setara dengan 64 juta ton sampah per tahun. Peningkatan jumlah sampah ini mencerminkan tantangan besar dalam pengelolaan sampah di seluruh wilayah Indonesia, terutama di tengah pertumbuhan populasi dan urbanisasi yang terus meningkat (Noer & Wistara, 2024).

Menurut *World Health Organization* (WHO) sampah adalah barang yang tidak digunakan, tidak dipakai, tidak disukai, atau dibuang yang berasal dari aktivitas manusia dan tidak muncul secara alami (Fiqih et al., 2023). Sampah yang tidak dikelola dengan baik dapat merusak kebersihan lingkungan, menimbulkan bau, serta menyebabkan berbagai penyakit. Kesadaran masyarakat terhadap bahaya ini masih tergolong rendah, dibuktikan dengan banyak yang membuang sampah sembarangan ke aliran sungai, dalam jumlah kecil maupun besar (Mustaghfiqh et al., 2020). Pengelolaan sampah yang tidak optimal dapat mengancam kesehatan masyarakat karena dapat memicu peningkatan populasi hewan pembawa penyakit seperti lalat dan tikus sehingga meningkatkan risiko pembawa penyakit menular (Komarudin et al., 2023). Dampak buruknya juga meluas ke aspek lingkungan, sosial, dan ekonomi mencakup pencemaran tanah dan udara, berkurangnya kelestarian alam, lingkungan kotor dan tidak nyaman, serta meningkatnya biaya akibat pencemaran (Fitri Agustin et al., 2022). Pengelolaan sampah yang berkelanjutan diperlukan untuk mengatasi permasalahan sampah agar tidak berdampak negatif pada lingkungan. Konsep dasar pengelolaan sampah bertujuan untuk mengurangi jumlah sampah, meminimalkan dampak negatif terhadap lingkungan, dan memanfaatkan sampah secara efektif (Wijayanti et al., 2023).

Pengumpulan, pemilahan, dan pengelolaan sampah adalah beberapa metode dalam penanganan sampah. Saat ini metode yang paling efektif adalah memisahkan sampah berdasarkan jenisnya seperti sampah organik, anorganik, serta bahan berbahaya dan beracun (B3) karena setiap jenis memerlukan penanganan yang spesifik (Lumban Tobing et al., 2024). Pemilahan sampah secara manual yang dilakukan secara langsung oleh manusia membutuhkan ruang yang luas dan tenaga kerja yang banyak agar proses pemilahan menjadi lebih cepat dan mudah, di mana seluruh sampah di pilah dan di bongkar sepenuhnya menggunakan tenaga manusia dari awal hingga akhir. Kesalahan dalam pengklasifikasi sampah secara manual juga kerap terjadi, hal ini disebabkan karena pekerja kehilangan fokus akibat terlalu banyak pekerjaan, seperti volume sampah yang

besar dan beragam jenis sampah yang harus diselesaikan (Kartiko et al., 2022).

Perkembangan teknologi memungkinkan penerapan klasifikasi gambar melalui pengenalan pola pada citra yang diinputkan dengan memanfaatkan kecerdasan buatan. Kecerdasan buatan memungkinkan sistem dapat mengidentifikasi dan mengenali pola-pola dalam gambar secara otomatis yang kemudian digunakan untuk mengklasifikasikan objek atau elemen di dalamnya (Bustamin et al., 2023). Salah satu bidang penting dalam kecerdasan buatan adalah *machine learning* yang menekankan pada pengembangan sistem yang mampu belajar secara otomatis dan efektif dari data yang tersedia. Sistem ini dirancang untuk meningkatkan kinerjanya seiring dengan bertambahnya data yang diproses, sehingga menjadi lebih akurat tanpa intervensi manusia. Ruang lingkup *machine learning* memiliki sub-bidang yang disebut *deep learning* yang menggunakan algoritma yang terinspirasi oleh cara kerja otak manusia khususnya jaringan saraf untuk memproses data dengan lebih mendalam dan kompleks. *Deep learning* memungkinkan pemodelan data yang lebih canggih terutama dalam tugas-tugas yang melibatkan pengenalan pola dan pemrosesan informasi visual (Halim, 2023). *Convolutional Neural Network* (CNN) adalah salah satu algoritma *deep learning* yang menerima *input* berupa gambar dan mengidentifikasi aspek atau objek dalam gambar yang dapat digunakan oleh mesin untuk belajar mengenali serta membedakan antara satu gambar dengan gambar lainnya (Dewi et al., 2024).

Beberapa kelemahan utama dalam model pembelajaran mendalam meliputi keterbatasan dataset, gambar yang terdistorsi dan kabur, *overfitting* pada model, serta daya komputasi yang terbatas (Krizhevsky et al., 2017). Terutama daya komputasi yang terbatas menjadi kendala signifikan dalam mengoptimalkan performa model, karena model memerlukan sumber daya yang besar untuk memproses dan melatih data secara efektif (Lin & Wu, 2023). Penerapan model pembelajaran mendalam seringkali memerlukan intensitas komputasi dan sumber daya yang besar, sehingga biayanya bisa menjadi tinggi dalam berbagai konteks penggunaan. Perangkat dengan keterbatasan sumber daya seperti perangkat *mobile* atau perangkat berbasis IoT memerlukan model yang lebih ringkas dan ringan secara komputasi. Permintaan akan pemrosesan *real-time* menuntut model yang dapat bekerja cepat dengan latensi rendah terutama pada perangkat yang memiliki kapasitas terbatas. Model dengan efisiensi tinggi menjadi sangat penting karena dapat mengurangi konsumsi energi dan menekan biaya operasional dalam

penerapannya di lapangan. Model dengan komputasi rendah seperti *MobileNet* dirancang khusus untuk aplikasi di perangkat *mobile* dan sistem tertanam dengan fokus utama pada pengurangan kompleksitas komputasi dan kebutuhan sumber daya tanpa mengorbankan akurasi (Mutasadirin & Falakh, 2024).

Berdasarkan pemaparan diatas, penelitian ini berfokus pada pengembangan model klasifikasi sampah menggunakan CNN dengan optimasi *hyperparameter tuning* arsitektur *MobileNet* untuk memastikan efisiensi komputasi dan akurasi yang optimal. Penggunaan CNN dengan optimasi *hyperparameter tuning* arsitektur *MobileNet* diharapkan dapat mengatasi tantangan dalam pemilihan sampah secara manual, sehingga dapat diterapkan dalam sistem pengelolaan sampah yang lebih efektif dan efisien.

TINJAUAN PUSTAKA

Penelitian dengan judul “Sistem Klasifikasi Limbah Menggunakan Metode *Convolutional Neural Network* (CNN) Pada *Web Service* Berbasis *Framework Flask*” yang dilakukan oleh Dacipta (2022) digunakan algoritma CNN dengan arsitektur VGGNet untuk melakukan klasifikasi sampah ke dalam sembilan kategori dengan 8371 gambar. Hasil penelitian ini menunjukkan nilai akurasi 69.77% dan nilai *loss* 0.34. Kelemahan dari penelitian ini adalah **akurasi rendah** yang tercermin dari hasil akurasi tertinggi sebesar **69.77%**. Akurasi ini masih tergolong rendah untuk aplikasi klasifikasi citra, terutama dalam konteks pengelolaan limbah di mana tingkat keakuratan yang lebih tinggi sangat penting untuk memastikan bahwa limbah dapat diklasifikasikan dengan benar dan efisien. Rendahnya akurasi model ini dapat mengakibatkan kesalahan dalam pemilihan limbah yang berdampak negatif terhadap proses daur ulang dan pengelolaan lingkungan secara keseluruhan.

Penelitian yang dilakukan oleh Ibnu Rasidi (2022) dengan judul “Klasifikasi Sampah Organik dan Non-Organik Menggunakan *Convolutional Neural Network*” digunakan algoritma CNN untuk melakukan klasifikasi sampah ke dalam dua kategori yaitu organik dan anorganik dengan 25.077 gambar. Pembagian data dilakukan dengan perbandingan 90% digunakan untuk data pelatihan dan 10% untuk data pengujian. Hasil penelitian ini menunjukkan akurasi pelatihan adalah 90% dan akurasi validasi adalah 88%. Sedangkan nilai *loss* pada data *training* adalah 0.298 dan pada data *testing* adalah 0.282. Beberapa kelemahan muncul dalam proses klasifikasi sampah organik, dengan tingkat akurasi yang hanya mencapai 62%. Rendahnya

akurasi ini disebabkan oleh kompleksitas sampah organik yang memiliki variasi bentuk dan warna lebih beragam dibandingkan sampah anorganik. Arsitektur CNN yang diterapkan belum sepenuhnya optimal dalam menangani variasi data tersebut sehingga diperlukan peningkatan akurasi.

Penelitian oleh Nuariputri (2023) dengan judul “Klasifikasi Jenis Sampah Menggunakan Base *ResNet-50*” digunakan arsitektur *ResNet50* sebagai *base model* untuk melakukan klasifikasi sampah ke dalam tujuh kategori dengan 2.751 gambar dengan menggunakan parameter uji seperti *epoch*, *batch size*, *optimizer*, dan *learning rate*. Hasil penelitian ini menunjukkan akurasi pelatihan 98%, kesalahan pelatihan 0.045, akurasi validasi 98%, dan kesalahan validasi 0.054. Arsitektur *ResNet-50* merupakan model yang dalam dan kompleks sehingga dapat menyebabkan waktu pelatihan lebih lama serta kebutuhan sumber daya komputasi yang lebih tinggi dibandingkan model yang lebih ringan. Kondisi ini menjadikan kendala dalam implementasi di lingkungan dengan sumber daya terbatas. Model yang terlalu kompleks juga berisiko mengalami *overfitting* terutama jika dataset yang digunakan tidak cukup banyak dan beragam.

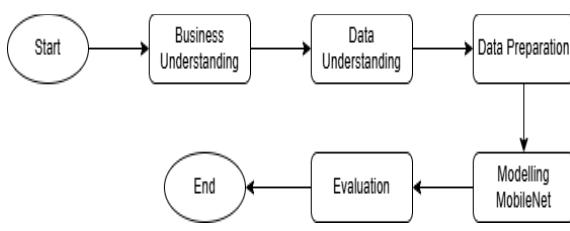
Penelitian lain yang dilakukan oleh Eva Sari Nainggolan (2024) dengan judul “Perbandingan Klasifikasi Jenis Sampah Menggunakan *Convolutional Neural Network* Dengan Arsitektur *ResNet18* dan *ResNet50*” dilakukan perbandingan antara arsitektur *ResNet18* dan *ResNet50* untuk mengetahui performa terbaik dari kedua arsitektur dengan 2.527 gambar dari enam kategori. Hasil penelitian ini menunjukkan akurasi *Resnet18* sebesar 98.69% dan *ResNet50* sebesar 99.41%. Penggunaan arsitektur *ResNet18* dan *ResNet50* memiliki kompleksitas yang tinggi. Kedua arsitektur ini memerlukan sumber daya komputasi yang signifikan, waktu pelatihan yang lama, dan penggunaan memori yang besar sehingga menjadi kendala dalam aplikasi *real-time*. Banyaknya parameter yang digunakan juga meningkatkan risiko model mengalami *overfitting* terutama jika dataset yang digunakan tidak cukup besar atau beragam.

Penelitian dengan judul “Implementasi Algoritma CNN *MobileNet* untuk Klasifikasi Gambar Sampah di Bank Sampah” yang dilakukan oleh Reza Faheruroji (2024) menggunakan arsitektur *MobileNet* sebagai *base model* untuk melakukan klasifikasi sampah ke dalam enam kategori dengan 2.773 gambar, hasil penelitian ini menunjukkan akurasi pelatihan 87.65%, kesalahan pelatihan 33.86%, akurasi validasi 89.84%, dan kesalahan validasi 32.93%. Dari enam kategori sampah masih terdapat tiga kategori dengan

hasil akurasi rendah dan menunjukkan ketimpangan yang cukup signifikan antar kategori. Tingkat kesalahan model juga cukup tinggi pada data pelatihan dan data validasi yang mengindikasikan kesulitan model dalam membedakan objek antar kategori. Optimasi diperlukan untuk mengatasi masalah tersebut agar dapat meningkatkan akurasi dan mengurangi kesalahan prediksi sehingga model dapat lebih efektif dalam membedakan objek antar kategori.

METODE PENELITIAN

Penelitian ini dilakukan dengan menerapkan metodologi *Cross-Industry Standard Process for Data Mining* (CRISP-DM). CRISP-DM merupakan sebuah standar yang digunakan dalam melakukan penambangan data (*data mining*) dan pengembangan *machine learning* (Fattah et al., 2022). Pada tahun 2020 di Indonesia CRISP-DM menjadi acuan Standar Kompetensi Kerja Nasional berdasarkan Keputusan Menteri Ketenagakerjaan No. 299 tahun 2020 (Yudiana et al., 2023). Terdapat 5 tahapan dalam metode CRISP-DM yaitu *Business Understanding*, *Data Understanding*, *Data Preparation*, *Modelling*, dan *Evaluation*.



Gambar 1. Alur Penelitian

Business Understanding

Tahap *business understanding* dilakukan untuk mengidentifikasi permasalahan utama yaitu pengelolaan sampah yang kurang efektif dan berakibat pada penanganan yang tidak tepat. Tujuan utama dari penelitian ini adalah mengembangkan model klasifikasi sampah yang mampu membedakan antara sampah organik, anorganik, dan B3. Model penelitian ini menjadi landasan bagi pengembangan sistem pengelolaan sampah yang lebih efektif dan efisien di masa depan.

Data Understanding

Tahap *data understanding* dilakukan untuk mengeksplorasi dan menganalisis dataset yang akan digunakan dalam pelatihan model. Dataset ini mencakup DatasetWaste1 untuk kategori sampah anorganik dengan jumlah data 2.417, Waste Classification Dataset untuk kategori sampah organik

dengan jumlah data 1.401, dan E Waste Image Dataset untuk kategori sampah B3 dengan jumlah data 3.000. Data – data tersebut kemudian diseleksi untuk memastikan kualitas serta relevansinya terhadap kondisi sampah di lingkungan yang menjadi fokus penelitian.

Dataset diseleksi untuk memastikan kualitas dan relevansi dengan cara menghilangkan data yang memiliki resolusi gambar rendah dan data yang tidak sesuai dengan kategori sampah. Melalui proses seleksi ini, dataset yang digunakan memiliki standar kualitas yang lebih tinggi sehingga dapat meningkatkan akurasi dan keandalan model dalam mengenali serta mengklasifikasikan sampah secara optimal.

Data Preparation

Tahap *data preparation* dilakukan untuk memastikan data siap digunakan dalam proses *modelling*. Ukuran awal gambar sebelum dinormalisasi berada dalam rentang di atas 224 x 224 piksel dan kurang dari 1000 x 1000 piksel dengan dimensi yang beragam. Gambar dalam dataset dinormalisasi ke ukuran 224 x 224 piksel sesuai dengan kebutuhan arsitektur model yang digunakan. *Class balancing* dilakukan dengan menggunakan metode *undersampling* untuk menangani ketidakseimbangan jumlah gambar disetiap kategori untuk memastikan model tidak bias terhadap kelas yang lebih dominan. Dataset kemudian dibagi menjadi tiga bagian utama yaitu data latih 70%, data validasi 20%, dan data uji 10% dengan tujuan untuk melatih, memvalidasi, dan mengevaluasi performa model dengan lebih akurat. Untuk meningkatkan variasi dalam dataset dan mencegah *overfitting*, dilakukan augmentasi gambar seperti *rotation*, *flip*, *zoom*, dan *brightness* yang diterapkan secara acak pada data latih untuk mensimulasikan berbagai kondisi visual yang berbeda.

Modelling

Tahap *modelling* dilakukan untuk melatih model dalam tugas klasifikasi. Pada tahap ini model dikembangkan menggunakan algoritma CNN dengan arsitektur *MobileNet* yang terkenal dengan efisiensi komputasi dan kinerjanya yang baik pada perangkat dengan keterbatasan sumber daya. *MobileNet* menggunakan pendekatan *depthwise separable convolution* yang memisahkan konvolusi menjadi dua langkah yaitu *depthwise convolution* untuk memproses setiap saluran input secara terpisah dan *pointwise convolution* untuk menggabungkan hasil dari *depthwise convolution*. Optimasi *hyperparameter tuning* adalah proses yang bertujuan untuk mencari

nilai optimal dari *hyperparameter* dalam model *machine learning* (Andini et al., 2022). Teknik *sequential hyperparameter tuning* digunakan dalam optimasi untuk menentukan nilai terbaik dari *hyperparameter*. Teknik ini dilakukan secara bertahap dengan menyesuaikan parameter dalam suatu urutan tertentu. Pemilihan *hyperparameter* yang tepat sangat penting karena dapat mempengaruhi kinerja, kecepatan pelatihan, dan kemampuan generalisasi model. Optimasi *hyperparameter tuning* diterapkan dengan pemilihan parameter seperti *optimizer* (Adam, RMSprop, dan SGD), *learning rate* (0.01, 0.001, dan 0.0001), *batch size* (16, 32, dan 64), dan jumlah *neuron* (64, 128, dan 256). Rangkaian proses data *preparation*, *modelling*, dan *evaluation* dijalankan menggunakan *Google Colaboratory*. Penggunaan *Google Colaboratory* dipilih karena mendukung berbagai *library* selama proses pelatihan yang terhubung dengan *google drive* secara gratis tanpa beban komputasi yang berlebih. *Google Colaboratory* yang digunakan selama proses pelatihan menggunakan spesifikasi yaitu GPU T4, RAM sistem 12.7 GB, RAM GPU 15 GB, dan kapasitas penyimpanan disk 112.6 GB.

Evaluation

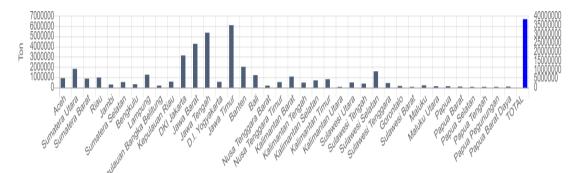
Tahap *evaluation* dilakukan untuk menilai kinerja model yang telah melalui proses *modelling*. Model diuji untuk mengukur *matrix* seperti *accuracy*, *precision*, *recall*, *f1-score* serta menggunakan *confusion matrix* untuk melihat hasil klasifikasi. Evaluasi mencakup ukuran model, biaya komputasi, FLOPS, analisis data *training* dan data *testing*, dan perbandingan dengan penelitian sebelumnya.

HASIL DAN PEMBAHASAN

Business Understanding

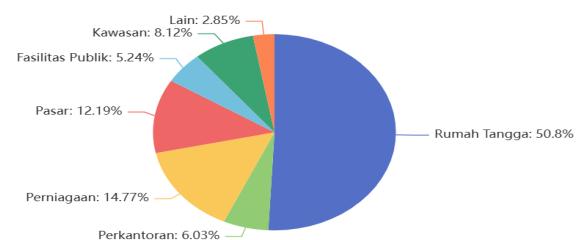
Pengelolaan sampah menjadi salah satu permasalahan utama di Indonesia dengan tingginya volume sampah yang dihasilkan setiap hari disebabkan oleh peningkatan populasi dan urbanisasi penduduk. Sampah tersebut membutuhkan penanganan yang efektif untuk mengurangi dampak terhadap lingkungan dan kesehatan.

Berdasarkan data Sistem Informasi Pengelolaan Sampah Nasional tahun 2023 jumlah total sampah yang dihasilkan adalah 38.264.345 ton / tahun dari 366 kabupaten / kota di seluruh Indonesia.



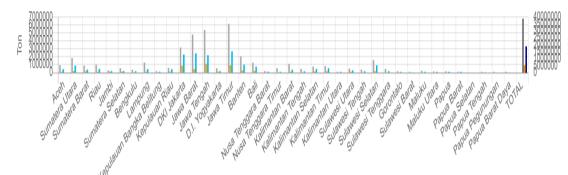
Gambar 2. Jumlah Sampah di Indonesia

Sumber penghasil sampah di Indonesia berasal dari berbagai sektor yaitu rumah tangga, perkantoran, perniagaan, pasar, fasilitas publik, kawasan, dan lainnya.



Gambar 3. Sumber Penghasil Sampah

Capaian kinerja pengelolaan sampah tahun 2023 secara keseluruhan adalah 18.402.801 ton / tahun dari 366 kabupaten / kota di seluruh Indonesia. Berdasarkan data tersebut diperoleh data capaian kinerja pengelolaan sampah 18.402.801 ton / tahun dari total sampah yang dihasilkan 38.264.345 ton / tahun. Capaian ini menunjukkan tingkat pengelolaan sampah mencapai 48.09% dan tergolong rendah dalam sebuah penanganan sampah yang kompleks sehingga perlu adanya sebuah peningkatan dalam pengelolaan sampah berkelanjutan.



Gambar 4. Capaian Kinerja Pengelolaan Sampah di Indonesia

Pengelolaan sampah secara manual dengan menggunakan tenaga kerja manusia dalam pemilahan sampah berdasarkan jenisnya tanpa dukungan teknologi rentan terhadap kesalahan klasifikasi karena pekerja kehilangan fokus akibat tingginya volume dan keragaman jenis sampah. Kesalahan pemilahan secara manual ini dapat mempengaruhi efektivitas pengelolaan sampah dan proses daur ulang.

Berdasarkan kondisi yang telah diuraikan tujuan penelitian ini adalah mengembangkan model klasifikasi sampah berbasis *Convolutional Neural Network* (CNN) dengan arsitektur *MobileNet* untuk mengoptimalkan proses pemilahan sampah secara otomatis. Penulis melakukan optimasi *hyperparameter tuning* pada arsitektur *MobileNet* dengan parameter *optimizer*, *learning rate*, *batch size*, dan jumlah *neuron* untuk memperoleh nilai kombinasi terbaik dari parameter tersebut. Model dalam penelitian ini mampu mengenali jenis sampah organik, anorganik, dan B3 dengan tingkat akurasi tinggi dan tetap mempertahankan efisiensi komputasi sehingga dapat diimplementasikan pada perangkat dengan kapasitas terbatas.

Data Understanding

Dataset yang digunakan merupakan kombinasi dari beberapa sumber dataset kaggle yang dipilih berdasarkan kesesuaian kategori sampah untuk mencakup variasi yang relevan dengan kondisi nyata. Dataset yang digunakan dalam penelitian ini adalah sebagai berikut:

1. DatasetWaste1

Dataset ini berisi kategori sampah anorganik dengan jumlah total 2.417 gambar. Kategori ini mencakup berbagai jenis sampah anorganik yang terdiri dari plastik, logam, kaca, kertas, dan karton (<https://www.kaggle.com/datasets/talithaalda/datas-etwaste1>).

2. Waste Classification Dataset

Dataset ini berisi kategori sampah organik dengan total 1.401 gambar. Kategori ini mencakup berbagai jenis sampah organik yang terdiri dari sisa makanan, sayur, buah, dedaunan, dan bahan alami lainnya yang mudah terurai (<https://www.kaggle.com/datasets/shubhamdivakar/waste-classification-dataset>).

3. E Waste Image Dataset

Dataset ini berisi kategori sampah B3 dengan total 3.000 gambar. Kategori ini mencakup berbagai jenis sampah B3 yang terdiri dari baterai, komponen komputer, dan perangkat elektronik (<https://www.kaggle.com/datasets/akshat103/e-waste-image-dataset>).

Proses seleksi dilakukan untuk memastikan kualitas serta relevansi data sehingga sesuai dengan kebutuhan klasifikasi sampah dalam penelitian ini. Seleksi dilakukan dengan memilih data yang berkualitas dan sesuai dengan kebutuhan.

Data Preparation

Data preparation pada penelitian ini mencakup normalisasi ukuran gambar, *class balancing*, pembagian dataset, dan augmentasi gambar.

1. Normalisasi Ukuran Gambar

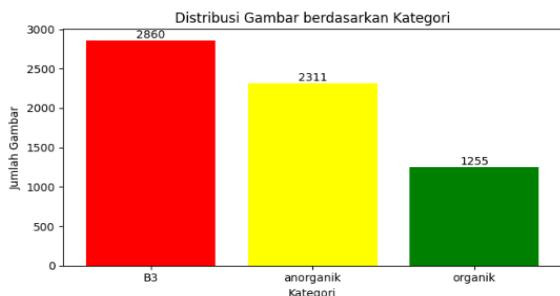
Tahap normalisasi ukuran gambar dilakukan dengan mengubah ukuran gambar menjadi 224 x 224 piksel yang merupakan standar input arsitektur *MobileNet* yang akan digunakan. Ukuran awal gambar sebelum dinormalisasi berada dalam rentang di atas 224 x 224 piksel dan kurang dari 1000 x 1000 piksel dengan dimensi yang beragam. Teknik normalisasi yang digunakan adalah kombinasi *center cropping* dan *resizing*, dimana gambar dipotong dari bagian tengah untuk menjaga fokus pada area utama gambar dan kemudian dirubah ukurannya menjadi 224 x 224 piksel. Normalisasi ukuran dilakukan dengan tujuan untuk menjaga konsistensi data dan memastikan bahwa model dapat mengolah semua gambar dengan resolusi yang seragam serta dapat membantu mempercepat proses pelatihan serta meningkatkan efisiensi dalam penggunaan sumber daya komputasi.



Gambar 5. Normalisasi Ukuran Gambar

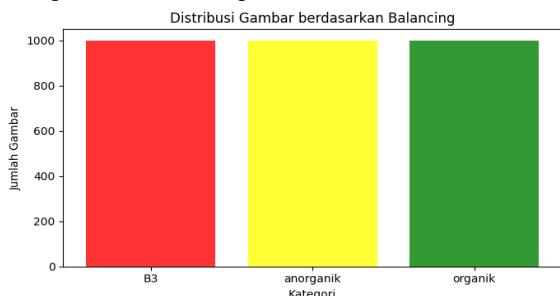
2. Class Balancing

Tahap *class balancing* dilakukan dengan menerapkan teknik *random undersampling* untuk mengurangi jumlah data pada kategori dominan agar proporsi jumlah gambar setiap kategori menjadi seimbang. Teknik *random undersampling* dilakukan dengan memilih sampel secara acak dari kategori yang memiliki jumlah data lebih banyak hingga mencapai jumlah yang seimbang dengan kategori lainnya. *Class balancing* dilakukan dengan tujuan untuk memastikan bahwa model tidak memiliki bias terhadap kategori tertentu dan dapat mengenali setiap kategori dengan akurasi yang lebih baik.



Gambar 6. Distribusi Gambar sebelum Class Balancing

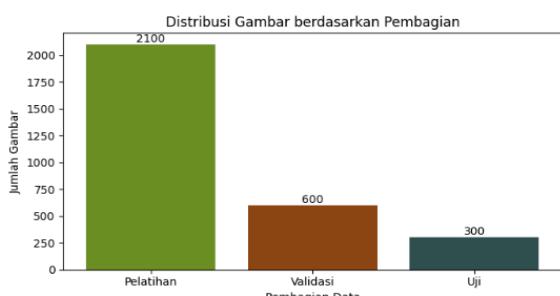
Hasil *class balancing* menunjukkan bahwa jumlah data pada setiap kategori sampah telah berhasil disamakan dengan masing-masing 1.000 data. Keseimbangan ini menjadikan data lebih representatif untuk pelatihan model.



Gambar 7. Distribusi Gambar setelah Class Balancing

3. Pembagian Dataset

Tahap pembagian dataset dilakukan dengan membagi data menjadi tiga komponen utama yaitu data latih (70%), data validasi (20%), dan data uji (10%) (Bitra & Dewi, 2024). Pembagian dataset dilakukan dengan tujuan untuk menyediakan data yang cukup pada setiap tahap pelatihan, validasi, dan pengujian sehingga model dapat dilatih dengan baik, diperbaiki secara berkala untuk mencegah *overfitting*, serta diuji secara objektif pada data yang tidak pernah dilihat sebelumnya untuk mengukur performa akhir model.



Gambar 8. Distribusi Gambar berdasarkan Pembagian

4. Augmentasi Gambar

Tahap augmentasi gambar dilakukan dengan menerapkan teknik *rotation*, *flip*, *zoom*, dan *brightness*. Augmentasi gambar dilakukan dengan tujuan untuk meningkatkan variasi dalam dataset dan mencegah masalah *overfitting* dengan mensimulasikan berbagai kondisi visual yang mungkin ditemui di lapangan. Proses augmentasi diterapkan pada data pelatihan menggunakan *ImageDataGenerator* karena mampu melakukan augmentasi secara *real time* selama proses pelatihan tanpa memerlukan penyimpanan tambahan untuk data hasil augmentasi. Augmentasi dilakukan secara *on the fly* selama proses pelatihan secara dinamis pada setiap *batch* data yang diproses oleh model. Hasil dari augmentasi tidak menghasilkan data baru secara fisik melainkan hanya memodifikasi gambar secara langsung saat proses pelatihan berlangsung.



Gambar 9. Augmentasi Gambar

Modelling

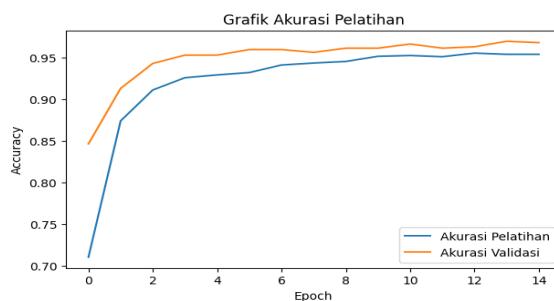
Modelling dalam penelitian ini dibangun menggunakan algoritma CNN dengan arsitektur *MobileNet*. Arsitektur *MobileNet* dirancang untuk melakukan ekstraksi fitur secara efisien melalui teknik *depthwise separable convolution* yang memungkinkan model untuk tetap ringan namun tetap akurat dalam melakukan klasifikasi pada dataset sampah yang digunakan.

Optimasi *hyperparameter tuning* dilakukan untuk memperoleh performa terbaik dari model. Proses ini bertujuan menemukan kombinasi parameter optimal untuk mencapai hasil klasifikasi maksimal. Parameter yang dioptimasi antara lain *optimizer* (Adam, RMSprop, dan SGD), *learning rate* (0.01, 0.001, dan 0.0001), *batch size* (16, 32, dan 64), dan jumlah *neuron* (64, 128, dan 256). Optimasi dilakukan menggunakan teknik *sequential hyperparameter tuning* untuk mengeksplorasi kombinasi nilai yang memberikan performa terbaik. Teknik optimasi ini terinspirasi dari penelitian sebelumnya yang menggunakan pendekatan

serupa dan diterapkan kembali untuk melihat efektivitasnya dalam penelitian ini. Perangkat keras yang digunakan dalam penelitian ini yaitu laptop dengan spesifikasi OS (Windows 11 Home Single Language), CPU (Intel Pentium Silver N6000 @1.10GHz 1.11 GHz), RAM (4 GB), Storage (512 GB). Optimasi dengan teknik *sequential hyperparameter tuning* dilakukan dengan langkah – langkah sebagai berikut:

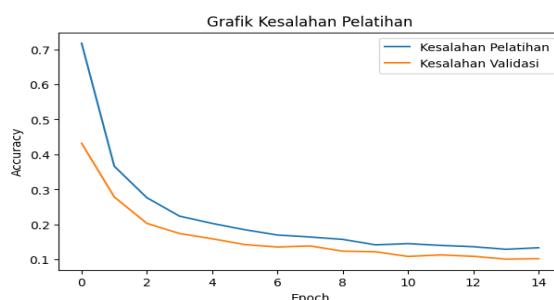
1. Skenario Uji *MobileNet*

Penelitian ini melakukan pengujian pada arsitektur *MobileNet* tanpa adanya pengaturan atau perubahan pada parameter. Hasil pengujian ini memberikan gambaran mengenai performa awal model dalam mengklasifikasikan sampah berdasarkan kategori yang ditentukan serta menjadi acuan untuk mengukur efektivitas optimasi *hyperparameter tuning* yang dilakukan pada tahap berikutnya.



Gambar 10. Grafik Akurasi Pelatihan *MobileNet*

Berdasarkan gambar di atas grafik akurasi pelatihan mengalami peningkatan dalam setiap *epoch* selama 15 *epoch* mulai dari 0.5687 hingga 0.9544 yang menunjukkan arsitektur *MobileNet* melakukan proses pembelajaran yang baik dalam data yang diberikan.



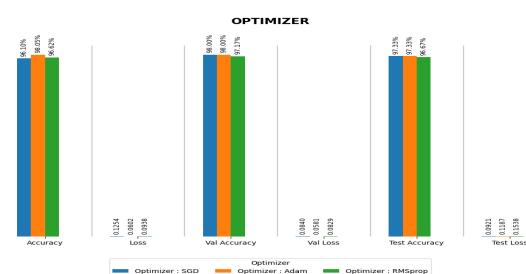
Gambar 11. Grafik Kesalahan Pelatihan *MobileNet*

Berdasarkan gambar di atas grafik kesalahan pelatihan mengalami penurunan dalam setiap *epoch* selama 15 *epoch* mulai dari 0.9572 hingga 0.1319 yang menunjukkan arsitektur *MobileNet* melakukan

proses pembelajaran yang baik dalam data yang diberikan.

2. Skenario Uji Parameter *Optimizer*

Penelitian ini melakukan pengujian terhadap parameter *optimizer*. Parameter *optimizer* merupakan salah satu parameter yang berperan penting dalam pelatihan model yang digunakan untuk memperbarui bobot pada model agar bisa belajar dari data yang diberikan. *Optimizer* yang diuji dalam penelitian ini adalah Adam, RMSprop, dan SGD.



Gambar 12. Skenario Uji Parameter *Optimizer*

Berdasarkan gambar di atas hasil perbandingan dari *optimizer* Adam, RMSprop, dan SGD menunjukkan bahwa *optimizer* Adam memberikan performa terbaik dalam proses pelatihan model dengan akurasi validasi sebesar 98.00% yang mencerminkan kemampuan unggul dalam memperbarui bobot model secara efisien untuk mencapai generalisasi yang baik. *Optimizer* Adam dipilih sebagai *optimizer* terbaik dan akan digunakan dalam pengujian parameter berikutnya.

3. Skenario Uji Parameter *Learning Rate*

Penelitian ini melakukan pengujian terhadap parameter *learning rate*. Parameter *learning rate* merupakan salah satu parameter yang berperan penting dalam pelatihan model yang digunakan untuk seberapa besar perubahan yang dilakukan model disetiap tahapan pembelajaran. *Learning rate* yang diuji dalam penelitian ini adalah 0.01, 0.001, dan 0.0001.



Gambar 13. Skenario Uji Parameter *Learning Rate*

Berdasarkan gambar di atas hasil perbandingan dari *learning rate* 0.01, 0.001, dan 0.0001 menunjukkan bahwa *learning rate* 0.01 memberikan performa terbaik dalam proses pelatihan model dengan akurasi validasi sebesar 98.33% yang mencerminkan efektivitas dalam memperbarui bobot model secara optimal tanpa mengorbankan stabilitas pembelajaran. *Learning rate* 0.01 dipilih sebagai *learning rate* terbaik dan akan digunakan dalam pengujian parameter berikutnya.

4. Skenario Uji Parameter *Batch Size*

Penelitian ini melakukan pengujian terhadap parameter *batch size*. Parameter *batch size* merupakan salah satu parameter yang berperan penting dalam pelatihan model yang digunakan untuk jumlah data yang diproses sekaligus dalam satu proses pelatihan. *Batch size* yang diuji dalam penelitian ini adalah 16, 32, dan 64.

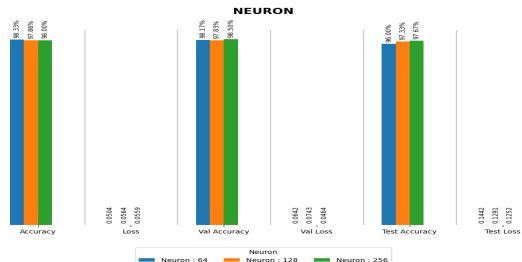


Gambar 14. Skenario Uji Parameter *Batch Size*

Berdasarkan gambar di atas hasil perbandingan dari *batch size* 16, 32, dan 64 menunjukkan bahwa *batch size* 32 memberikan performa terbaik dalam proses pelatihan model dengan akurasi validasi sebesar 98.33% yang mencerminkan efisiensi dalam memanfaatkan data untuk pembaruan bobot model. *Batch size* 32 dipilih sebagai *batch size* terbaik dan akan digunakan dalam pengujian parameter berikutnya.

5. Skenario Uji Parameter Jumlah *Neuron*

Penelitian ini melakukan pengujian terhadap parameter jumlah *neuron*. Parameter jumlah *neuron* merupakan salah satu parameter yang berperan penting dalam pelatihan model yang digunakan untuk kapasitas model untuk mempelajari pola – pola data. Jumlah *neuron* yang diuji dalam penelitian ini adalah 64, 128, dan 256.

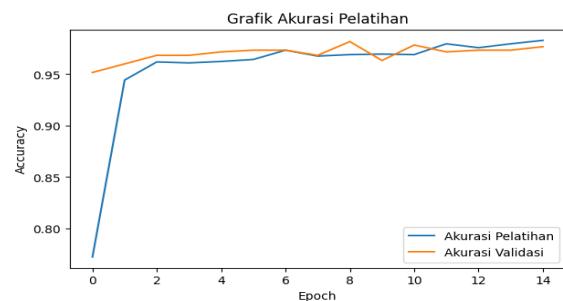


Gambar 15. Skenario Uji Jumlah *Neuron*

Berdasarkan gambar di atas hasil perbandingan dari jumlah *neuron* 64, 128, dan 256 menunjukkan bahwa jumlah *neuron* 256 memberikan performa terbaik dalam proses pelatihan model dengan akurasi validasi sebesar 98.50% yang mencerminkan kemampuan model untuk mempelajari pola dalam data secara efektif. Jumlah *neuron* 256 dipilih sebagai jumlah *neuron* terbaik dan akan digunakan dalam pengujian parameter berikutnya.

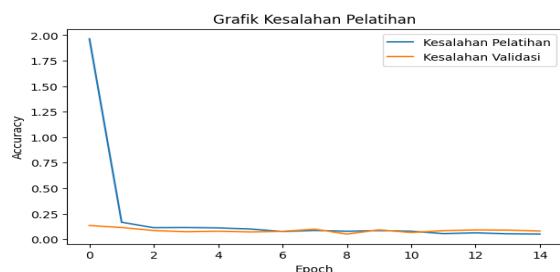
6. Skenario Uji *Mobilenet Optimasi*

Penelitian ini melakukan pengujian pada arsitektur *MobileNet* dengan kombinasi *hyperparameter tuning* terbaik yang telah diperoleh dari proses pengujian sebelumnya yaitu parameter *optimizer* (Adam), *learning rate* (0.01), *batch size* (32), dan jumlah *neuron* (256). Kombinasi dari nilai parameter tersebut diuji untuk mengevaluasi kinerja arsitektur *MobileNet* dalam klasifikasi sampah setelah dilakukan optimasi.



Gambar 16. Grafik Akurasi Pelatihan *MobileNet* Optimasi

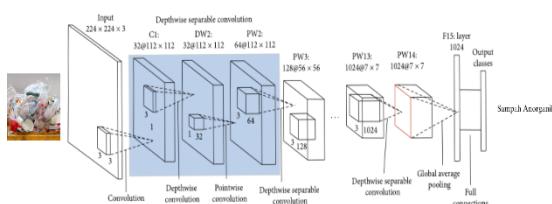
Berdasarkan gambar di atas grafik akurasi pelatihan mengalami peningkatan dalam setiap *epoch* selama 15 *epoch* mulai dari 0.5951 hingga 0.9810 yang menunjukkan arsitektur *MobileNet* dengan optimasi *hyperparameter tuning* melakukan proses pembelajaran yang baik dalam data yang diberikan.



Gambar 17. Grafik Kesalahan Pelatihan *MobileNet* Optimasi

Berdasarkan gambar di atas grafik kesalahan pelatihan mengalami penurunan dalam setiap *epoch* selama 15 *epoch* mulai dari 4.9212 hingga 0.0510 yang menunjukkan arsitektur *MobileNet* dengan optimasi *hyperparameter tuning* melakukan proses pembelajaran yang baik dalam data yang diberikan.

Proses ekstraksi fitur pada arsitektur *MobileNet* dapat diilustrasikan melalui *feature maps* yang menunjukkan bagaimana gambar input diproses dari tahap awal hingga menghasilkan output klasifikasi.



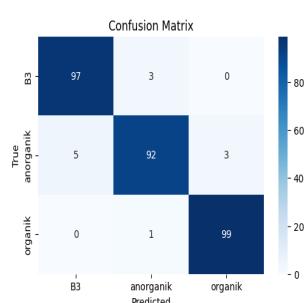
Gambar 18. *Feature Maps* Input sampai Output Klasifikasi

Evaluation

Evaluation pada penelitian ini dilakukan untuk menilai seberapa efektif model dalam mengklasifikasikan sampah berdasarkan kategori yang telah ditentukan.

Confusion Matrix

Confusion matrix adalah alat penting dalam evaluasi performa model klasifikasi yang menghitung jumlah prediksi benar dan salah pada setiap kategori.

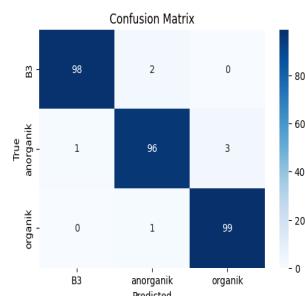


Gambar 19. Confusion Matrix Sebelum Optimasi

Tabel 1. Evaluasi *Confusion Matrix* Sebelum Optimasi

Kategori	Precision	Recall	F1-Score
B3	0.95	0.97	0.96
Anorganik	0.96	0.92	0.94
Organik	0.97	0.99	0.98
Akurasi: 96%			

Optimasi *hyperparameter tuning* diterapkan pada arsitektur *MobileNet* untuk memperoleh kombinasi parameter terbaik yang dapat meningkatkan akurasi model dengan tetap mempertahankan biaya komputasi yang rendah.



Gambar 20. Confusion Matrix Sesudah Optimasi

Tabel 2. Evaluasi *Confusion Matrix* Sesudah Optimasi

Kategori	Precision	Recall	F1-Score
B3	0.99	0.98	0.98
Anorganik	0.97	0.96	0.96
Organik	0.97	0.99	0.98
Akurasi: 98%			

Berdasarkan nilai *confusion matrix* sebelum dan sesudah dioptimasi terdapat peningkatan nilai yang menunjukkan optimasi berhasil memperbaiki kemampuan model dalam melakukan klasifikasi jenis sampah.

Tabel 3. Selisih Nilai Optimasi

MobileNet	MobileNet + Hyperparameter Tuning	Selisih
96%	98%	2%

Berdasarkan tabel di atas menunjukkan bahwa penerapan *hyperparameter tuning* pada arsitektur *MobileNet* menghasilkan peningkatan akurasi sebesar 2% dari 96% menjadi 98%. Hal tersebut menunjukkan bahwa optimasi *hyperparameter tuning* mampu meningkatkan performa model dalam mengenali dan mengklasifikasikan jenis sampah dengan lebih baik.

Berdasarkan evaluasi *confusion matrix*, kategori sampah anorganik memiliki tingkat kesalahan prediksi tertinggi dengan nilai *recall* terendah (0.96) yang menunjukkan kesulitan model dalam mendeteksi semua sampel dengan benar. Kesalahan ini disebabkan oleh kemiripan visual dengan kategori lain terutama organik serta efek augmentasi *brightness* yang dapat mengaburkan perbedaan warna antar kategori.

Ukuran Model

Ukuran model adalah kapasitas memori yang diperlukan untuk menyimpan model setelah dilatih.

Tabel 4. Evaluasi Ukuran Model

Kondisi Model	Ukuran Model
Sebelum Optimasi	12.57 MB
Sesudah Optimasi	13.32 MB

Berdasarkan tabel di atas menunjukkan bahwa ukuran model sebelum dan sesudah optimasi memiliki nilai yang berbeda yaitu 12.57 MB sebelum dilakukan optimasi dan 13.32 MB setelah dilakukan optimasi. Hal tersebut menunjukkan bahwa optimasi *hyperparameter tuning* berhasil meningkatkan performa model meskipun disertai dengan peningkatan ukuran model sebesar 0.75 MB.

Biaya Komputasi

Biaya komputasi adalah jumlah sumber daya yang dibutuhkan untuk melatih dan menjalankan model.

Tabel 5. Evaluasi Biaya Komputasi

Kondisi Model	Waktu Pelatihan	Waktu Inferensi	CPU	GPU
Sebelum Optimasi	9 Menit 53.58 Detik	1699.68 ms	4.5%	8.16 MB
Sesudah Optimasi	9 Menit 10.89 Detik	1055.73 ms	3.0%	8.17 MB

Berdasarkan tabel di atas menunjukkan bahwa biaya komputasi sebelum dan sesudah optimasi memiliki nilai yang berbeda. Waktu pelatihan berkurang dari 9 menit 53.58 detik menjadi 9 menit 10.89 detik yang menunjukkan peningkatan efisiensi selama proses pelatihan. Waktu inferensi per gambar berkurang dari 1699.68 ms menjadi 1055.73 ms yang menunjukkan proses klasifikasi menjadi lebih cepat dan efisien. Penggunaan CPU berkurang dari 4.5%

menjadi 3.0% menunjukkan penurunan yang relatif signifikan, namun penggunaan GPU mengalami peningkatan meskipun relatif kecil dari 8.16 MB menjadi 8.17 MB.

FLOPS

Flops adalah jumlah operasi *floating point* yang dapat dijalankan oleh model dalam satu detik yang menunjukkan efisiensi komputasi model.

Tabel 6. Evaluasi FLOPS

Kondisi Model	FLOPS
Sebelum Optimasi	1.146 GFLOPS
Sesudah Optimasi	1.146 GFLOPS

Berdasarkan tabel di atas menunjukkan bahwa nilai FLOPS sebelum dan sesudah optimasi memiliki nilai yang sama yaitu 1.146 GFLOPS. Hal tersebut menunjukkan bahwa operasi floating point yang dieksekusi oleh model tetap konstan dan tidak mempengaruhi kompleksitas komputasi model, sehingga dapat disimpulkan bahwa optimasi *hyperparameter tuning* berhasil meningkatkan performa model tanpa menambah beban operasi komputasi yang harus dijalankan dan menjadikan model dapat diimplementasikan dengan optimal pada perangkat dengan keterbatasan sumber daya komputasi.

Data Training dan Data Testing

Perbandingan antara data *training* dan data *testing* adalah proses untuk mengevaluasi kemampuan model dalam menggeneralisasi data baru.

Tabel 7. Evaluasi Data Training dan Data Testing

Kondisi Model	Matrix	Data Training	Data Testing
Sebelum Optimasi	Accuracy	96.81%	96%
Optimasi	Loss	0.1100	0.1201
Sesudah Optimasi	Accuracy	98.29%	98%
Optimasi	Loss	0.0483	0.1013

Berdasarkan tabel di atas menunjukkan bahwa performa model sebelum dan sesudah optimasi mengalami peningkatan baik pada data training maupun data testing. Sebelum optimasi nilai *accuracy* pada data *training* adalah 96.81% dan pada data *testing* 96% dengan nilai *loss* pada data *training* 0.1100 dan pada data *testing* 0.1201. Setelah dilakukan optimasi performa model mengalami peningkatan signifikan dengan nilai *accuracy* pada data *training* adalah 98.29% dan pada data *testing* 98% dengan nilai *loss*

pada data *training* 0.0483 dan pada data *testing* 0.1013. Perbedaan nilai yang kecil pada *accuracy* dan *loss* antara data *training* dan *testing* menunjukkan bahwa model berhasil menghindari *overfitting*.

Hasil penelitian ini dapat digeneralisasi ke dalam dataset sampah lain yaitu dengan menggunakan data yang diambil secara langsung (data primer) untuk mencoba performa model yang dihasilkan dan memperoleh hasil klasifikasi yang maksimal.

Perbandingan Penelitian Terdahulu

Perbandingan dengan penelitian terdahulu adalah evaluasi untuk menilai apakah model yang dikembangkan dalam penelitian ini mampu mencapai hasil yang lebih baik dibandingkan dengan hasil penelitian sebelumnya pada bidang dan algoritma yang sama.

Tabel 8. Evaluasi Penelitian Terdahulu

Judul, Nama, dan Tahun	Evaluasi Matrix
Klasifikasi Sampah Menggunakan Base ResNet-50 (Nuariputri et al., 2023)	Hasil evaluasi dari penggunaan arsitektur <i>ResNet-50</i> adalah tingkat akurasi mencapai 98.70% dengan melakukan modifikasi pada base model dengan menambah layer dan melakukan <i>fine tuning</i> .
Perbandingan Klasifikasi Sampah Menggunakan Convolutional Neural Network Dengan Arsitektur ResNet18 dan ResNet50 (Eva Sari Nainggolan et al., 2024)	Hasil evaluasi dari penggunaan arsitektur <i>ResNet-50</i> dan <i>ResNet-18</i> adalah tingkat akurasi mencapai 99.41% dan 98.69% pada perbandingan kedua arsitektur tersebut dengan waktu pelatihan 34 menit 44 detik dan 22 menit 19 detik.
Implementasi Algoritma CNN MobileNet untuk Klasifikasi Gambar Sampah di Bank Sampah (Reza Fahcruroji et al., 2024)	Hasil evaluasi dari penggunaan arsitektur <i>MobileNet</i> adalah tingkat akurasi mencapai 87.65% pada data pelatihan dan 89.84% pada data validasi, kemudian nilai <i>loss</i> pada data pelatihan adalah 33.86% dan 32.93% pada data validasi.
Implementasi Algoritma Convolution Neural Network pada Klasifikasi	Hasil evaluasi dari penggunaan arsitektur <i>MobileNet</i> adalah tingkat akurasi mencapai 91% pada data pelatihan dan 89% pada data validasi, kemudian

Limbah dengan Arsitektur <i>MobileNet</i> (Oktafiandi, 2024)	nilai <i>loss</i> pada data pelatihan adalah 0.25 dan 0.30 pada data validasi.
Pemanfaatan <i>Machine Learning</i> untuk Optimalisasi Limbah dengan Model <i>MobileNetV2</i> pada Aplikasi Android (Rismayadi et al., 2024)	Hasil evaluasi dari penggunaan arsitektur <i>MobileNetV2</i> adalah tingkat akurasi mencapai 95.45% pada data pelatihan dan 84.83% pada data validasi.
Hasil Penelitian	Hasil dari penelitian ini berdasarkan evaluasi dari penggunaan arsitektur <i>MobileNet</i> adalah tingkat akurasi mencapai 96%. Optimasi <i>hyperparameter tuning</i> menghasilkan nilai terbaik yaitu <i>optimizer</i> (<i>Adam</i>), <i>learning rate</i> (0.01), <i>batch size</i> (32), dan jumlah <i>neuron</i> (256) yang dikombinasikan untuk meningkatkan akurasi model. Optimasi <i>hyperparameter tuning</i> pada arsitektur <i>MobileNet</i> menghasilkan nilai akurasi mencapai 98% dan meningkatkan nilai akurasi dengan selisih 2%. Waktu pelatihan model adalah 9 menit 53.58 detik dan waktu prediksi adalah 1699.68 ms dengan ukuran model 12.57 MB. Setelah dilakukan optimasi <i>hyperparameter tuning</i> waktu pelatihan model adalah 9 menit 10.89 detik dan waktu prediksi adalah 1055.73 ms dengan ukuran model 13.32 MB. Nilai <i>FLOPS</i> model dalam penelitian ini adalah 1.146 GFLOPS.

Berdasarkan tabel perbandingan di atas menunjukkan bahwa penelitian yang telah dilakukan menggunakan arsitektur *MobileNet* dengan optimasi

hyperparameter tuning telah memperoleh hasil akurasi dengan nilai 98% menggunakan parameter terbaik yaitu *optimizer* Adam, *learning rate* 0.01, *batch size* 32, dan jumlah *neuron* 256. Hasil penelitian ini telah berhasil mendekati hasil atau setara dengan penggunaan arsitektur *ResNet* yang mencapai akurasi hingga 98 – 99%, dan jika dibandingkan dengan penggunaan arsitektur *MobileNet* menunjukkan adanya peningkatan akurasi yang signifikan. Penelitian ini juga menunjukkan bahwa arsitektur *MobileNet* memiliki kompleksitas yang rendah sehingga dapat digunakan dalam perangkat dengan keterbatasan sumber daya tanpa mengorbankan tingkat akurasi dengan nilai FLOPS 1.146 GFLOPS.

Kebaharuan dalam penelitian ini terletak pada penerapan optimasi *hyperparameter tuning* pada arsitektur *MobileNet* yang berhasil meningkatkan akurasi model secara signifikan dibandingkan penelitian sebelumnya yang menggunakan arsitektur serupa. Penelitian terdahulu dengan arsitektur *MobileNet* umumnya mencapai akurasi sekitar 87% - 91%, sementara penelitian ini menunjukkan bahwa optimasi *hyperparameter tuning* yang tepat akurasi model dapat ditingkatkan dengan akurasi mencapai 98%.

KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan menggunakan algoritma *Convolutional Neural Network* (CNN) dengan arsitektur *MobileNet* dalam penelitian ini menunjukkan kemampuan untuk mengklasifikasikan jenis sampah dengan tingkat akurasi sebesar 96%. Penerapan optimasi *hyperparameter tuning* pada arsitektur *MobileNet* dengan teknik *sequential* yang digunakan dalam penelitian ini menunjukkan tingkat akurasi yang lebih tinggi dalam mengklasifikasikan jenis sampah. Parameter yang digunakan dalam optimasi *hyperparameter tuning* yaitu *optimizer*, *learning rate*, *batch size*, dan jumlah *neuron*.

Optimasi dengan teknik *sequential* *hyperparameter tuning* menghasilkan nilai terbaik dari setiap parameter yaitu *optimizer* (Adam), *learning rate* (0.01), *batch size* (32), dan jumlah *neuron* (256) yang dikombinasikan untuk meningkatkan akurasi model. Hasil evaluasi model menunjukkan tingkat akurasi sebesar 98% dan mengalami peningkatan 2% dibandingkan dengan tingkat akurasi sebelum diterapkan optimasi *hyperparameter tuning*. Penelitian ini berhasil melakukan klasifikasi jenis sampah dengan tingkat akurasi yang tinggi melalui optimasi *hyperparameter tuning* dan tetap mempertahankan

biaya komputasi rendah dengan menggunakan arsitektur *MobileNet*.

Penelitian ini memiliki kelebihan yaitu model yang dikembangkan memiliki efisiensi komputasi tinggi berkat arsitektur *MobileNet*. Optimasi *hyperparameter tuning* berhasil mencapai akurasi 98% menunjukkan performa klasifikasi yang baik. Model ini juga berpotensi diterapkan dalam sistem pemilahan sampah otomatis. Penelitian ini memiliki kekurangan yaitu penggunaan dataset sekunder yang mungkin tidak sepenuhnya mencerminkan kondisi nyata, klasifikasi yang masih terbatas pada tiga kategori utama, dan waktu pelatihan yang lama saat menggunakan *cross validation* yang menunjukkan bahwa model belum sepenuhnya *robust* dalam menangani variasi data.

Berdasarkan hasil penelitian ini, pengembangan lebih lanjut dapat difokuskan pada penggunaan dataset dengan jumlah lebih besar dan proses pengambilan data secara langsung dari kondisi lingkungan nyata untuk meningkatkan relevansi dan akurasi hasil. Perbandingan performa dengan arsitektur CNN lain yang memiliki biaya komputasi rendah juga diperlukan guna menentukan arsitektur terbaik. Pengembangan model ini ke dalam sebuah sistem berbasis aplikasi *mobile* atau berbasis IoT juga diharapkan mampu meningkatkan manfaat praktis penelitian terutama dalam penerapannya di lingkungan masyarakat. Peningkatan *robust* model juga diperlukan agar lebih stabil dan efisien dalam proses pelatihan serta lebih adaptif terhadap variasi data.

DAFTAR PUSTAKA

- Andini, E., Reza Faisal, M., Herteno, R., Adi Nugroho, R., & Abadi, F. (2022). Peningkatan Kinerja Prediksi Cacat Software Dengan Hyperparameter Tuning Pada Algoritma Klasifikasi Deep Forest. In *Jurnal MNEMONIC* (Vol. 5, Issue 2). <https://github.com/bharlow058/AEEEM-and-other>
- Bitra, M., & Dewi, C. (2024). Penggunaan YOLOv8 untuk Deteksi Penyakit Daun Kopi (Vol. 5, Issue 4).
- Bustamin, A., Zaman, B., Khusnul Hakim, F., Teknik Gowa, K., Poros Malino, J. K., Bontomarannu, K., Kharisma Makassar, S., Baji Ateka No, J., Mappakasunggu, B., Mamajang, K., & Makassar, K. (2023). Sistem Multi Klasifikasi Sampah Anorganik dengan Menggunakan Transfer Learning (Vol. 8, Issue 1). <http://journal.uinalauddin.ac.id/index.php/insypro>
- Dacipta, P. N., & Putra, R. E. (2022). Sistem Klasifikasi Limbah Menggunakan Metode Convolutional Neural Network (CNN) Pada

- Web Service Berbasis Framework Flask.
Journal of Informatics and Computer Science, 03.
- Dewi, S., Ramadhani, F., & Djasmayena, S. (2024). Klasifikasi Jenis Jerawat Berdasarkan Gambar Menggunakan Algoritma CNN (Convolutional Neural Network). *Hello World Jurnal Ilmu Komputer*, 3(2), 68–73.
<https://doi.org/10.56211/helloworld.v3i2.518>
- Eva Sari Nainggolan, C., Nasir, M., Udariansyah, D., Informatika, T., Bina Darma, U., Jenderal Ahmad Yani No, J., Seberang Ulu, K. I., & Selatan, S. (2024). *Perbandingan Klasifikasi Jenis Sampah Menggunakan Convolutional Neural Network Dengan Arsitektur ResNet18 dan ResNet50 The Classification Comparison of Waste Type Using Convolutional Neural Network by Resnet18 and Resnet50 Architecture*. 16(1), 76.
<https://doi.org/10.22303/csrld.1.1.2022.01-10>
- Fattah, A. M. M., Voutama, A., Heryana, N., & Sulistiowati, N. (2022). Pengembangan Model Machine Learning Regresi sebagai Web Service untuk Prediksi Harga Pembelian Mobil dengan Metode CRISP-DM. *JURIKOM (Jurnal Riset Komputer)*, 9(5), 1669.
<https://doi.org/10.30865/jurikom.v9i5.5021>
- Fiqih, M. N., Syaiful, S., & Aminda, R. S. (2023). Penempatan Bak Sampah Organik, Anorganik, dan B3 dengan Konsep Go Green Perumahan Budi Agung RW 03 / RT 05. *Jurnal Pengabdian Masyarakat UIKA Jaya: SINKRON*, 1(2), 71.
<https://doi.org/10.32832/jpmuj.v1i2.1907>
- Fitri Agustin, A., Nurlailia, A., Sulistyorini, L., Kesehatan Lingkungan, D., Kesehatan Masyarakat, F., Airlangga, U., Mulyorejo, K., Surabaya, K., Timur, J., & Ilmu Kesehatan dan Ilmu Alam, S. (2022). *Analisis Pengetahuan, Sikap, dan Ketersediaan Sarana dengan Tindakan Pengelolaan Sampah Rumah Tangga serta Dampaknya pada Masyarakat*.
http://journal.stikeskendal.ac.id/index.php/PSK_M
- Halim, G. J. (2023). Rancang Bangun Smart Engine Untuk Mendeteksi Jenis Biji Kopi Dengan Menerapkan Model Convolutional Neural Network. *Jurnal Sistem Informasi Dan Ilmu Komputer*, 1(3), 61–72.
<https://doi.org/10.59581/jusiik-widyakarya.v1i3.910>
- Ibnul Rasidi, A., Pasaribu, Y. A. H., Ziqri, A., & Adhinata, F. D. (2022). Klasifikasi Sampah Organik dan Non-Organik Menggunakan Convolutional Neural Network. *Jurnal Teknik Informatika Dan Sistem Informasi*, 8(1).
<https://doi.org/10.28932/jutisi.v8i1.4314>
- Julia Lingga, L., Yuana, M., Aulia Sari, N., Nur Syahida, H., & Sitorus, C. (2024). Sampah di Indonesia: Tantangan dan Solusi Menuju Perubahan Positif. *INNOVATIVE: Journal Of Social Science Research*, 4(4), 12235–12247.
- Kartiko, Prima Yudha, A., Dimas Aryanto, N., & Arya Farabi, M. (2022). Klasifikasi Sampah di Saluran Air Menggunakan Algortima CNN. *Indonesian Journal of Data and Science*, 3(2), 72–81. <https://doi.org/10.56705/ijodas.v3i2.33>
- Komarudin, A., Rosmajudi, A., & Hilman Program Pascasarjana STIA YPPT Priatim Tasikmalaya, A. (2023). Implementasi Kebijakan dalam Pengelolaan Sampah Rumah Tangga dan Sampah Sejenis Sampah Rumah Tangga di Kecamatan Indihiang Kota Tasikmalaya. *Indonesian Journal Of Education And Humanity*, 3.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). *ImageNet Classification with Deep Convolutional Neural Networks*.
<http://code.google.com/p/cuda-convnet/>
- Lin, C. L., & Wu, K. C. (2023). Development of revised ResNet-50 for diabetic retinopathy detection. *BMC Bioinformatics*, 24(1).
<https://doi.org/10.1186/s12859-023-05293-1>
- Lumban Tobing, J., Utama, M. K., Septyanda, R. B., Listiyanto, Z., Saputri, F. S., Effendi, K., & Prameswari, P. (2024). Sosialisasi Budaya Pemilahan Sampah Sebagai Langkah Menuju Lingkungan yang Bersih di Kelurahan Warungboto. *Jurnal Pengabdian Kolaborasi Dan Inovasi IPTEKS*, 2(4), 1397–1405.
<https://doi.org/10.59407/jpki2.v2i4.1216>
- Mustaghfiroh, U., Ni'mah, L. K., Sundusiyah, A., Addahlawi, H. A., & Hidayatullah, A. F. (2020). Implementasi Prinsip Good Environmental Governance dalam Pengelolaan Sampah di Indonesia. *Bina Hukum Lingkungan*, 4(2), 279.
<https://doi.org/10.24970/bhl.v4i2.106>
- Mutasodirin, M. A., & Falakh, F. M. (2024). Efficient Weather Classification Using DenseNet and EfficientNet. *Jurnal Informatika: Jurnal Pengembangan IT*, 9(2), 173–179.
<https://doi.org/10.30591/jpit.v9i2.7539>
- Noer, S., & Wistara, S. V. (2024). Edukasi Sadar Sampah serta Pembuatan Kertas Daur Ulang di SDIT Insan Madani. *Jurnal PKM (Pengabdian Kepada Masyarakat)*, 7(4), 484.
<https://doi.org/10.30998/jurnalpkm.v7i4.23262>
- Nuariputri, J., Maimunah, & Sukmasetya, P. (2023). Klasifikasi Jenis Sampah Menggunakan Base ResNet-50. *Jurnal Ilmiah Komputasi*, 22(3).
<https://doi.org/10.32409/jikstik.22.3.3380>
- Oktafandi, H. (2024). *Implementasi Algoritma Convolution Neural Network pada Klasifikasi Limbah dengan Arsitektur MobileNet*.
<https://winco.cilacapkab.go.id>
- Reza Fahcruroji, A., Yunita Wijaya, M., Fauziah, I., Sains dan Teknologi, F., Syarif Hidayatullah Jakarta Jl Ir Juanda No, U. H., Ciputat Tim, K., & Tangerang Selatan, K. (2024). *Implementasi*

- Algoritma CNN MobileNet untuk Klasifikasi Gambar Sampah di Bank Sampah. 11(1).*
Rismayadi, D. A., Muharam, M. A., Kreatif, F. I., Teknik Informatika, D., & Bandung, U. T. (2024). *Pemanfaatan Machine Learning untuk Optimalisasi Limbah dengan Model MobileNetV2 pada Aplikasi Android. 06.*
Sulistio, P., & Syahruddin, S. R. (2024). Pembatasan Import Sampah Sebagai Komitmen Indonesia Dalam Upaya Penanganan Perubahan Iklim Global. *JATIJAJAR LAW REVIEW*, 3(1), 36. <https://doi.org/10.26753/jlr.v3i1.1281>
- Wijayanti, A. N., Dhokhikah, Y., & Rohman, A. (2023). Analisis partisipasi masyarakat terhadap pengelolaan sampah di Kecamatan Sumbersari, Kabupaten Jember, Provinsi Jawa Timur. *Jurnal Pengelolaan Lingkungan Berkelanjutan (Journal of Environmental Sustainability Management)*, 28–45. <https://doi.org/10.36813/jplb.7.1.28-45>
- Yudiana, Y., Yulia Agustina, A., & Nur Khofifah, dan. (2023). *Prediksi Customer Churn Menggunakan Metode CRISP-DM Pada Industri Telekomunikasi Sebagai Implementasi Mempertahankan Pelanggan* (Vol. 8, Issue 1). <http://e-journal.lp2m.uinjambi.ac.id/ojp/index.php/ijoeb>